

Yapay Sinir Ağları Yöntemleri Kullanılarak PVP İçeren Nanoliflerin Çaplarının Tahmini

İsmail Yıldız^{1*}, Süleyman KARABULUT²

¹Afyon Kocatepe Üniversitesi, İncehisar Meslek Yüksekokulu, Makine ve Metal Teknolojileri Bölümü, 03750, Afyonkarahisar/Türkiye
(ORCID: 0000-0002-9207-591X), iyildiz@aku.edu.tr

²MİGYEM Kırıkkale/ Türkiye, skarabulut03@gmail.com

(İlk Geliş Tarihi 07.06.2023 ve Kabul Tarihi 25.09.2023)

(DOI: 10.29228/JCHAR.70520)

Sorumlu Yazar: iyildiz@aku.edu.tr, Afyon Kocatepe Üniversitesi, İncehisar Meslek Yüksekokulu, Makine ve Metal Teknolojileri Bölümü, 03750, Afyonkarahisar/Türkiye, +905437284508

Referans gösterme: Yıldız, I., Karabulut, S., Yapay Sinir Ağları Yöntemleri Kullanılarak PVP İçeren Nanoliflerin Çaplarının Tahmini. *Journal of Characterization*, cilt: 3, No:3, 77-86, 2023.

Öz

Yapay sinir ağları (YSA), insan beyninin özelliklerinden biri olması sonucu öğrenme metodu ile yeni bilgilerin ortaya çıkarılması ve keşfedilmesi, yeni bilgilerle modelleme yapılması, veri ilişkilendirmeden yorumlamaya kadar bilgilerin otomatik şekilde gerçekleştirmek için geliştirilen bir yöntemdir. Karmaşık sistemlerde kümeleme, kontrol ve optimizasyon gibi yöntemlerin yanı sıra insan beyni ve ortaya çıkabilecek geleceğe yönelik değerlerin tahmininde de kullanılmaktadır. Bu çalışmada, öncelikli olarak elektro eğirme yöntemi ile Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi kullanılarak nanolifler elde edilmiş ve nanoliflere yapay sinir ağları veri seti oluşturulmasıyla akış hızı, iğne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj değerleri ölçülmüştür. Elde edilen nanoliflerin mikroyapı analizleri taramalı elektron mikroskopu (SEM) ile çapları ise Fibraquant programı ile belirlenmiştir. Yapay Sinir Ağları algoritmalarıyla girdi ve çıktı değişkenleri olarak nanoliflerin çapını etkileyen farklı modeller oluşturulmuş ve bu modellerden ortaya çıkan sonuçlar literatürle karşılaştırılmıştır.

Anahtar Kelimeler: Yapay sinir ağları, nanolif, algoritma

Estimation of Diameters of PVP Containing Nanofibers Using Artificial Neural Network Methods

Abstract

Artificial neural networks (ANN), being one of the features of the human brain, is a method developed to reveal and discover new information with the learning method, to model with new information, to automatically realize information from data association to interpretation. In complex systems, it is used in the prediction of the human brain and the future values that may arise, as well as methods such as clustering, control and optimization. In this study, nanofibers were obtained by using Polyvinylpyrrolidone (PVP) polymer, water and alcohol solution primarily by electrospinning method, and the flow rate, distance between needle tip and collector plate and applied voltage values were measured by creating an artificial neural network data set to nanofibers. The microstructure analyzes of the obtained nanofibers were determined by scanning electron microscopy (SEM) and their diameters were determined by the Fibraquant program. With Artificial Neural Networks algorithms, different models

affecting the diameter of nanofibers as input and output variables were created and the results from these models were compared with the literature.

Keywords: Artificial neural networks, nanofiber, algorithm

1. Giriş

İnsanların günlük hayatında uygulamalarıyla daha fazla yerini almaya başlayan nanoteknoloji yapılan bilimsel araştırmalar göz önüne alındığında 21. yüzyılda birçok alanda etkili olacak farklı bir teknoloji olarak ortaya çıkmaktadır. Yeni uygulama alanları ile karşımıza çıkan nanoteknolojinin, malzeme ve üretim, tıp ve sağlık, biyoteknoloji, elektronik ve bilgisayar, uzay ve havacılık, çevre ve enerji, tarım, bilim ve eğitim, savunma başlıkları altında incelendiği görülmektedir [1].

Veri madenciliği (data mining), verilerden anlamlı bilgi çıkaran, farklı sektörlerde kullanım yeri olan önemli yöntemlerden birisidir. Veri madenciliğine bakıldığında, verileri toplayarak ön işleme sonrası modellenmesi ve değerlendirilmesi aşamalarının sonucu olarak nitelendirilmektedir. Elde edilen veriler, madenciliğin sahip olduğu verilerle ilgili ambarlardan, veri tabanlarından ve veri saklayabilen her ortamdan sağlanabilmektedir. Veri madenciliğinde ortaya çıkan veriler son derece önemlidir. Çünkü toplanan veri, aranan bilgiyi anlamlı hale getirecek bir yapıda olmalıdır [2].

Veri tek başına anlam içermemekle birlikte, verinin işlenmesine imkân sağlayacak veri depolama ve veri analiz yöntemlerinin ilerlemesiyle, veriden anlamlı çıkarımlar sağlayarak, iş süreçlerinde daha etkin kararlar alınabilmektedir. Böylece, tüketicinin taleplerini hızlı ve doğru bir biçimde karşılayabilecek mal/hizmetler geliştirilebilecek, işletmenin maliyetlerinin azaltılması ve diğer işletmelere karşı rekabet avantajı sağlanabilmektedir. Bu sebeple, eğitimden sağlık sektörüne, tarımdan finansa ve bilişimden ulaşırmaya kadar pek çok alanda veri madenciliği giderek yaygınlaşmaktadır [3,4].

Gelende kullanılan metotlarıyla çözilemeyen problemlerin çözümünde yaygın kullanım alanı olan Yapay Sinir Ağları (YSA), sınıflandırmadan modellemeye, veri ilişkilendirmeden yorumlamaya kadar, kümeleme, kontrol ve optimizasyona kadar birçok farklı alanlarda kullanılırken, geleceğe yönelik değerlerin tahmini kullanıldığı önemli alanlardan biri olarak karşımıza çıkmaktadır. Yapay Sinir Ağları (YSA), insan beyninin özelliklerini taklit ederek, öğrenme metodu ile yeni bilgiler üretilme ve keşfetme yeteneklerine herhangi bir destek olmaksızın otomatik şekilde gerçekleştirmek için geliştirilen bir yöntemdir. YSA'ların, günümüzde finanstan, pazarlamaya ve çeşitli mühendislik alanlarına kadar geniş bir kullanım yeri bulunmaktadır [5].


Endüstrinin birçok alanında kullanılan nanoteknoloji veri madenciliği tekniklerinde ele alınmış, Yapay Sinir Ağları yöntemlerinde sınırlı sayıda araştırmalar yapıldığı görülmüştür. Bu çalışmada, Yapay Sinir Ağları algoritmaları nanoliflerin çaplarının tahmin edilmesi amacıyla kullanılmıştır.

Yapay Sinir Ağları kullanılarak nanoliflerin çaplarının tahmini ile ilgili benzer çalışmalarla karşılaşılmış, polivinilpirolidon (PVP) polimer çözeltisi nanoliflerin Yapay Sinir Ağları ve Derin Öğrenme Algoritmaları ile çaplarının tahmininin yapıldığı bir tez veya makaleye rastlanmamış, nanoteknoloji alanında veri madenciliği konusunu kapsayan çalışmalar değerlendirilmiştir. Elektrospinning prosesinde nanoliflerin çaplarının tahmini hakkında literatür varken, Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi parametresi kullanılarak çap tahmini üzerine bulunmamaktadır.

2. Materyal ve Metot

2.1. Yapay Sinir Ağları

Yapay sinir hücrelerinden oluşan YSA'lar yapısal olarak biyolojik sinir hücrelerinden esinlenerek oluşturulmuştur. Biyolojik sinir hücrelerini girdiler, ağırlıklar, toplama ve aktivasyon fonksiyonu ile çıkışlar oluşturmaktadır.



Şekil 2.1 Yapay Sinir Hücresi

Bir yapay sinir hücresine çevreden gelen bilgiler ($x_1, x_2, \dots, x_m$) girdilerdir. Bu bilgiler giriş olarak yapay sinir hücrelerine gönderilmektedir. Yapay sinir hücresine gönderilen girdilerin sinir üzerindeki etkisini belirleyen katsayılar ($w_1, w_2, \dots, w_m$) ağırlıklardır. Her bir girdinin kendisine ait ağırlığı bulunmaktadır [6].

Bir hücreye gelen net girdi Toplama Fonksiyonu ile hesaplanmaktadır. Ağırlıklı toplamı bulma fonksiyonunda, basit bir yapıya sahip girdi değerleri ve ağırlıklarının çarpımı toplanarak bir aktivasyon fonksiyonuna gönderilerek sonuç elde edilmektedir. Formülasyonu Denklem 1’de yer almaktadır.

$$NET = \sum_i^n x_i w_i \quad (1)$$

Literatürde karşılaşılan toplama fonksiyonu türleri fonksiyonları Çizelge 2.1’deki gibidir.

Çizelge 2.1 Toplama Fonksiyonu Türleri

Net Giriş	Açıklama
Çarpım $NET = \prod_i G_i A_i$	Ağırlık değerleri girdilerle çarpılmasıyla bulunan değerlerin birbirleri ile çarpılması ile NET girdi hesaplanmaktadır.
Maksimum $NET = \max(G_i A_i)_{i=1 \dots N}$	N adet girdi içinden ağırlıklar ile çarpılıp en büyük olan yapay sinir hücresinin NET girdisi olarak girdisi ortaya çıkmaktadır.
Minimum $NET = \min(G_i A_i)_{i=1 \dots N}$	N adet girdi içinden ağırlıklar ile çarpılıp en küçüğü yapay sinir hücresinin NET girdisi olarak girdisi ortaya çıkmaktadır.
Çoğunluk $NET = \sum_i \text{sng}(G_i A_i)$	N adet girdi içinden ağırlıklar ile çarpılıp pozitif ve negatif olanların sayısı bulunarak, büyük olan sayı hücrenin NET girdisi olarak kabul edilmektedir.
Tarihli Toplam $NET = \text{Net}(\text{Eski}) + \sum G_i A_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanarak önceden gelen bilgilere eklenir. Bu şekilde hücrenin net girdisi bulunmaktadır.

Sinir düğümlerine ulaşan giriş sinyallerini işleyerek nöronun çıkış sinyallerini belirleyen, verilerin yapılarını öğrenerek anlamlı sonuçlar oluşturan ve transfer fonksiyonu olarak da adlandırılan fonksiyon Aktivasyon fonksiyonudur. YSA'da veri ve probleme göre çeşitli aktivasyon fonksiyonları kullanılmaktadır. Aktivasyon fonksiyonunda YSA'nın çoğu zaman doğrusal olmayışından dolayı çoğunlukla lineer olmayan bir fonksiyon seçilmektedir. Doğrusal fonksiyonların tercih edilmesindeki neden, girdinin çıktı ile doğru orantılı olmasından kaynaklanmaktadır [7,8].

2.2 Yapay Sinir Ağlarının Yapısı

YSA'lar, yapay sinir hücrelerinin birbiri ile bağlanması sonucunda oluşan yapılardır. Giriş, Ara (Gizli) ve Çıkış Katmanı olarak üç ana katmanda izlenmektedir. Ağa, girdi katmanı aracılığı ile iletilen bilgiler ara katmanlarda işlenir, işlenen bilgiler çıktı katmanına gönderilirler. Burada bilgi işlemede ifade edilen, ağa gelen bilgilerin ağa ait ağırlık değerlerinin kullanılmasıyla çıktıya dönüştürülmesi işlemidir. Ağırlıkların doğru değerlere sahip olması, ağın girdileri için doğru çıktıları üretebilmesinde çok önemlidir. Ağ, birden çok nöron ve gizli katmana sahipse çok katmanlı (multilayer), tek bir katmana sahipse tek katmanlı (single layer) olarak nitelendirilmektedir [9].

2.3 Tek Katmanlı Ağ


Tek katmanlı YSA'lar sadece girdi ve çıktı katmanlarından oluşur. Çıktı üniteleri bütün girdi ünitelerine (X) bağlanmakta ve her bağlantıya ait bir ağırlık (W) bulunmaktadır. Doğrusal olmayan problemlerde tercih edilmemektedir [10].



Şekil 2.2 Tek katmanlı ağ yapısı

2.4 Çok Katmanlı Yapay Sinir Ağları


Çok katmanlı YSA'lar, giriş katmanı ve çıkış katmanları ile gizli (hidden) katmanlarından oluşmaktadır. Karmaşık problemler için çözüm elde etmek amacıyla ve doğrusal olmayan problemlerde kullanılmaktadır. Birden çok girdi ve gizli katmana sahiptirler. Problemin akışına göre gizli katman sayısının artırılabilmesi veya azaltılabilmesi mümkündür. Gizli katmanlar, problem yapısına göre farklı fonksiyonlarla işlenerek çıktı katmanına iletilmesini sağlamaktadır [10].



Şekil 2.3 Çok katmanlı ağ yapısı

2.5 İleri Beslemeli Yapay Sinir Ağları


İleri beslemeli YSA'da hücreler katmanlar şeklinde düzenlenmiş, bir katmanda bulunan hücreye ait çıkışlar bir sonraki katmana ağırlıklar üzerinden giriş olarak verilmiştir. Çevreden elde edilen bilgiler, giriş katmanında herhangi bir değişikliğe uğratılmadan ara yani gizli katmandaki hücrelere iletilmektedir. Bilgi, ara ve çıkış katmanında işlenerek ağın çıkışı belirlenmektedir. YSA'ya, örnekler ile örneklerden elde edilmesi gereken çıktılar yani beklenen çıktılar verilmektedir. Burada ağ problemi çözmek ve uzayı üretmek için kendisine verilen örnekleri kullanarak genellemeler yapar, böylece çözüm uzayı hem sonuçlar hem de çözümler sunabilmektedir [11].



Şekil 2.4 İleri Beslemeli Yapay Sinir Ağları

2.6 Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli YSA'larda, en az bir hücrenin çıkışı kendisine veya diğer hücrelere giriş olarak verilirken, geri besleme genellikle bir geciktirme elemanı üzerinden gerçekleştirilir. Bu durumda, bir katman içindeki hücreler arasında veya farklı katmanlar arasındaki hücrelerle geri besleme gerçekleştirilebilir. Bu nedenle, geri beslemeli YSA'lar, geri beslemenin yapıldığı şekle göre farklı davranabilir ve doğrusal olmayan dinamik bir davranış sergileyebilir [12].



Şekil 2.5 Geri Beslemeli Yapay Sinir Ağları


2.7 Yapay Sinir Ağının Eğitimi

Belirli bir probleme yönelik olarak bir ağın yapılandırılmasını müteakip ağın eğitim işlemine geçilir. Elde bulunan verilerin ağı sunulmasıyla ağın öğrenmesi sağlanır. Ağın bağlantı ağırlıkları problem türü ve kullanılan ağın yapısına göre daha önce belirlenen öğrenme kuralının kullanılması ile değiştirilebilmektedir. Ağırlık değerlerinin belirlenmesi ağı gösterilen örneklerin doğru çıktı üretmesi için önemlidir. Genelde başlangıç ağırlık değerleri rassal olarak seçilmektedir. Ağın eğitimi için kullanılan veri seti Eğitim Seti olarak ifade edilmektedir. Ağın eğitimi süresince aynı eğitim setinin defalarca ağı verilmesiyle ağırlıklar en uygun seviyeye getirilmektedir. Eğitim setinin tümünün ağı gösterilmesi olarak ifade edilen İterasyon (Epoch), genelde eğitim sürelerini ölçmede değerlendirilmektedir. YSA'nın eğitimi tamamlandıktan sonra öğrenme performansını ölçmek amacıyla yapılan denemeler ağın test edilmesi şeklinde ifade edilmektedir. Eğitim setini oluşturan verilerle hedeflenen

başarı sağlanmışsa ağ, daha önceden kullanmadığı verilerle test edilmektedir. Burada, test işleminin gerçekleştirildiği veri seti Test Seti olarak adlandırılmaktadır. Ağın ağırlık değerleri test işlemi gerçekleştirilirken değiştirilememektedir. Örnekler ağa gösterilerek ve ağın eğitiminden sonunda elde edilen ağırlık değerleri kullanarak, ağın daha önceden görmediği bu örnekler için çıktıların üretilmesi sağlanmaktadır. Üretilen bu çıktılara ait doğruluk dereceleri ağın öğrenmesi hakkında bilgiler verecek, sonucun iyi olması eğitimin performansının o kadar iyi olacağını ifade edecektir. Test seti ile hedeflenen sonuçlara ulaşırsa ağın eğitimi tamamlanmış olacaktır [13].

Yapılan çalışmada, nanoliflerin elde edilmesinde Polivinilpirolidon polimer, su ve alkol çözeltisi kullanılmıştır. Polivinilpirolidon polimer, piyasada PVP olarak adlandırılmaktadır. Bu polimer su içerisinde kolay bir şekilde çözünme özelliğine sahiptir. Polivinilpirolidon polimer, Sigma Aldrich firmasından temin edilmiştir.

Elektro çekim prosesini etkileyen önemli parametreden birisi de polimer jeti üzerinde etkisi olan dış etkenlerdir. Bu dış etkenler; polimer çözeltisine uygulanan voltaj, akış hızı, çözeltinin sıcaklığı, toplayıcının tipi ve çapı ile düze-toplayıcı arasındaki mesafe olarak bilinmektedir. Elektroegirme yöntemi ile püskürtme olarak kullanılacak polimer çözeltisi ya da eriyik ile lif oluşumunda öncelikle yüksek bir gerilim kullanılması yan sıra jet düzesinden ince kıl şeklinde çıkan polimer jeti, düzenin karşısına topraklamaya sahip oluşturulmuş hedefe doğru akmaktadır. Akma sırasında polimer jetinden çok ince lifcikler ortaya çıkarak saçılmakta ve nano çap boyutlarında lifler elde edilebilmektedir.



Şekil 2.6. Elektroegirme yöntemi düzeneği [6]

Elektroegirme yöntemiyle elde edilen nanoliflerin mikroyapı analizleri Afyon Kocatepe Üniversitesi Teknoloji Araştırma ve Uygulama Merkezinde bulunan (TUAM) LEO 1430 VP model Taramalı Elektron Mikroskobu (SEM) cihazı aracılığıyla yapılmıştır.

Laboratuvar ortamındaki SEM görüntülerinden Fibrquant uygulaması ile nanoliflerin yapı, çap ve dağılımı elde edilmiştir. Laboratuvarda yapılan deneylere ait deneysel veriler Matlab programı kullanılarak veri seti oluşturulmuştur. Bu veriler Matlab programı ile çözülmeden önce veri tutarsızlıklarını önlemek için tüm veriler normalize edilerek veri tekrarı en aza indirilmiş, giriş verilerinin tümü [0,1] aralığına indirgenmiştir.

Ağın eğitilmesi için programda bulunan Neural Network uygulaması kullanılmıştır. Çalışma kapsamında Yapay Sinir Ağları ile ilgili olarak yapılacak çalışmalar için MATLAB R2021A yer alan yapay sinir ağları alt modülü olan Matlab Neural Network Toolbox kullanılmıştır.

Çalışmada kullanılacak olan YSA modeli, ileri beslemeli geri yayılım ağıdır. Tahmin çalışmalarında çok kullanılıyor olması ve doğrusal olmayan modellerdeki tahmin başarısı bu yapay sinir ağının tercih edilmesinde önemli bir unsurdur.

Modeli oluştururken nanolif çapını etkileyecek faktörler belirlenmiştir. Nanolif çapının tahmin edilmesinde kullanılacak yapay sinir ağının eğitilmesi için veri setinde bulunan girdi değişkenleri Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi, akış hızı, iğne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj değeri ve çıktı olarak nanolif çapı olarak belirlenmiştir. Modelde 4 adet girdi 1 adet çıktı ve tek ara katman kullanılmıştır.

Modelin eğitimine geçilmeden önce modele ait girdi değişkenleri, gizli katmanlar ve çıktı değişkenleri ile katman sayıları tanımlamaları yapılmıştır. Birçok deneme yapılarak tahmin sonuçlarını etkileyen hücre sayısı, momentum katsayısı ve öğrenme katsayısı değerleri belirlenmeye çalışılmıştır. Yapılan denemeler sonucunda öğrenme katsayısı 0.9, momentum katsayısı 0.8, hücre sayısı 2 olarak belirlenmiştir. Ağın tipi İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop), giriş katmanında bağımsız değişken olarak polimer, su ve alkol çözeltisi, akış hızı, iğne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj değeri, gizli katman sayısı bir, aktivasyon fonksiyonu Hiperbolik Tanjant, çıktı katmanında bağımlı değişken olarak nanolif çapı, aktivasyon fonksiyonu Hiperbolik Tanjant ve performans fonksiyonu olarak da Ortalama Hata Kareleri (Mean Squared Errors,MSE) kullanılmıştır.


Korelasyon katsayısının karesi olan R kare, regresyon analizinde modele ait performansın değerlendirilmesi maksadıyla kullanılan istatistiksel bir ölçüttür. Modeldeki bağımlı değişkenin, değişkenliğin ne kadar olduğunun model tarafından açıklanabileceğini ölçer. Regresyon modelinde bağımsız değişken sayısı fazla ise model eğitim verilerine çok iyi uyabilse de teste istenen başarıyı gösteremeyebilir. Bu sebeple Düzeltilmiş R Kare kullanılmaktadır (Denklem 2) [14].

$$R^2 = 1 - (1 - R^2) \frac{n-1}{n-p-1} \quad (2)$$

Ortalama Kare Hatası (MSE) tahmin sonucunda elde edilen değerlerin gerçek değerlerden ne kadar farklı olduğuna yönelik mutlak bir değer vermektedir. Başarı değerlendirme ölçüsü olarak MSE, optimizasyon yöntemlerinde kullanılırken, daha iyi modeller kurmak üzere optimize edilmeye çalışılan bir fonksiyondur (Denklem 3) [14].

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \tilde{y}_i)^2 \quad (3)$$

Oluşturulacak YSA için ağın tipi, eğitim girdisi (input data)-çıktı verisi (target data), eğitim ve öğrenme için algoritmalar, performans fonksiyonu, katman, gizli hücre, nöron sayısı ve aktivasyon fonksiyonu tercihleri yapılmış ve Şekil 2.7’de yer alan YSA modeline göre ortaya çıkan yapay sinir ağı oluşturulmuştur. Kullanılan modelde “Ortalamadan sapmanın öğrenilmesi” amaçlandığından hiperbolik tanjant fonksiyonu tercih edilmiştir. Ağın eğitimi için kullanılan ve en uygun sonucun elde edilebilmesi maksadıyla Gradient Descent Algoritması tercih edilmiştir.




Şekil 2.7. Yapay sinir ağı

Bu aşamada “Train” sekmesinde altında bulunan ve öğrenme performansını etkileyen momentum, öğrenme ve çevrim sayısı değerlerinin seçimi yapılarak YSA’nın eğitimi başlatılmıştır. Eğitim, elde edilen veri seti için MSE fonksiyonunu en aza indirmek için ağırlık değerlerini belirlemektir. Bu noktada doğrulama seti ve eğitim seti ağda sunulmakta ve en küçük hata düzeyine ulaşmaya çalışılmaktadır.

3. Bulgular ve Tartışma


3.1 Yapay Sinir Ağları Sonuçların Test Edilmesi ve Değerlendirilmesi

YSA’nın eğitimi tamamlandıktan sonra iterasyonlardaki Eğitim, Doğrulama ve Test kümelerindeki hata değerlerine ait değişimi gösteren Şekil 3.1’deki grafik elde edilmiştir. Grafik incelendiğinde ağın eğitiminde en iyi performans, 257. iterasyonda elde edilmiştir.



Şekil 3.1 Eğitim, doğrulama ve test kümelerine ilişkin hata performansları

YSA'nın eğitimde; MSE hata oranını ve R ise eğitimin ne kadar iyi olduğunu göstermektedir. Momentum ve öğrenme katsayısı ile çevrim sayısı gibi öğrenmenin performansına etki eden parametreler seçilerek nöron sayısı deneme yanılma yolu ile belirlenmiş, MSE oranının minimum R oranının maksimum seviyede ve % 90 üzerinde olması hedeflenmiştir. Öğrenmenin tamamlanmasından sonra elde edilen regresyon grafiği Şekil 3.2'de gösterilmektedir. Regresyon grafiği incelendiğinde en yüksek değer 0.9497 ile test kümesine ait olduğu, 0.9462 ile öğrenme işleminin başarılı olduğu, belirlenen değişkenlerin 0.94 oranında nanoliflerin çaplarını etkilediği görülmektedir. Sistemin herhangi bir ezberleme yapıp yapmadığına baktığımızda eğitim R oranı ile test doğruluk oranı arasındaki farkın yüksek olmadığı, dolayısıyla bir ezberleme yapmadığı değerlendirilmektedir.



Şekil 3.2 Matlab'ta öğrenme, doğrulama ve test kümelerine ilişkin regresyon grafiği

Yapay Sinir Ağları ile yapılan tahmin sonuçlarının bir kısmı Çizelge 3.1'de gösterilmiştir.

Çizelge 3.1 Ölçülen gerçek değerler ile tahmin edilen değerler

Ölçülen Değer	Tahmin (YSA)	Hata (YSA)
1,269	1,3018	-0,0328
1,455	1,4789	-0,0239
1,757	1,5483	0,2087
0,573	0,6407	-0,0677
0,59	0,5684	0,0216
0,794	0,7529	0,0411
0,148	0,1546	-0,0066
0,149	0,1529	-0,0039
0,154	0,1521	0,0019

4. Sonuçlar

Tahmin, kesin bir süreç olmamakla birlikte, birtakım verilere dayanarak, gelecekteki bir olayın nasıl olacağını önceden öngörülmesidir. Tahmin modellemesi, karar vermede etkin bir rol oynamasından dolayı birçok alanda kullanılmaktadır. Birçok alanda tahmin modellemesi için kullanılan yöntemlerden biri olarak kullanılan yapay sinir ağları incelenmiş, uygulama alanları ve mimarileri tanıtılmıştır. Yapılan uygulamada YSA kullanılarak nanoliflerin çaplarının tahminine yönelik tahmin modelleri geliştirilmiştir.

Yapay Sinir Ağları kullanarak nanolif çaplarının tahmini yapan bir uygulama örneği olarak yapılan çalışmada, laboratuvar ortamında elde edilen nanoliflerin SEM görüntülerinden derlenen ve normalizasyon işlemine tabi tutulan bir veri setinin modellerdeki sonuçları kıyaslanmış, nanolif çaplarını tahmin etmek için yapay sinir ağlarının performansı incelenmiştir. Çalışmada nanoliflerin çapını etkileyen 4 adet bağımsız değişken girdi değişkeni olarak, nanolif çap değerleri ise çıktı değişkeni olarak kullanılmıştır.

Yapılan çalışmanın başarısını ölçebilmek için ölçülen değerlerle YSA ile ortaya çıkan sonuçlar ile karşılaştırılmıştır. Yapay Sinir Ağı, eğitim, test ve doğrulama aşamalarında yüksek regresyon ve düşük MSE (Ortalama Hata Kareleri) değerleri ile tahmin işlemi başarılı bir şekilde gerçekleştirmiştir. Uygulama neticesinde eğitim ve hata grafikleri incelendiğinde, amaçlanan öğrenmenin gerçekleştirildiği görülmektedir. Yapay sinir ağları ile gerçekleştirilen tahminde yüksek doğruluk ile tahmin gerçekleştirdiği belirlenmiştir.

Yapılan çalışma sonucunda bulunan sonuçlara göre Yapay Sinir Ağları tahmin becerisi yüksek araçlar olarak görülmektedir. Nanoliflerin çaplarının belirlenmesinde laboratuvar ortamında kullanılan deney materyalleri üretimi önemli bir maliyet oluşturmaktadır. Yapay Sinir Ağları yüksek tahmin becerisinden dolayı, geliştirilecek daha iyi modeller ile halihazırda yapılan testlerden daha az sayıda test yapmak, yüksek doğrulukta istenilen sonuçlara ulaşmak mümkün olabilecektir. Bu durum laboratuvar ortamında yapılan test maliyetlerin azalmasına imkân sağlayacaktır.

5. Teşekkür

Bu çalışma, Afyon Kocatepe Üniversitesi Bilimsel Araştırma Projeler Birimi 20.FEN.BİL.31 No'lu Projesi ile desteklenmiştir.

Etik Standartların Beyanı

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

Çıkar Çatışması

Bu çalışmada herhangi bir çıkar çatışması yoktur.

Kaynaklar

- [1] J. Uldrich and D. Newberrry, *Nanoteknoloji Gelecekteki İşlerinizi Nasıl Değiştirecek, Sıradaki Büyük şey Aslında Çok Küçük*, (Çev. Tolga Alıcı), İstanbul, Ledo Yayınları, 2005.
- [2] M. Ertem, “Bir Savunma Sanayi Firmasında Depo Bölgesi Atama Sisteminin Veri Madenciliği ve Makine Öğrenme Yaklaşımlarıyla İyileştirilmesi”, *Avrupa Bilim ve Teknoloji Dergisi*, vol. 34, pp. 501-506. 2022.
- [4] F. Ersöz, *Veri Madenciliği Teknikleri ve Uygulamaları (3. Baskı ed.)*, Seçkin Yayınevi, 303, Ankara, 2019.
- [4] M. Ersöz, A. Işıtan, M. Balaban, *Nanoteknoloji 1: Nanoteknolojinin Temelleri*, 274s, Denizli, 2018.
- [5] Z. Ağyar, *Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama*, Mühendis ve Makine, vol. 56(662), pp. 22-23, 2015.
- [6] M. Çuhadar, “Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi”, Doktora Tezi, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Isparta, 188s, 2006.
- [7] F. Şenocak, H. Kahveci, “Gün Öncesi Piyasasında PTF Dönemsel Ağırlıklı Fiyat Ortalama Tahmini”, *Dokuz Eylül Üniversitesi, Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, vol. 23(67), pp. 93-105, 2016.
- [8] M. Yücesoy, “Temizlik Sektöründe Yapay Sinir Ağları ile Talep Tahmini”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, 155s, 2011.
- [9] Yıldırım, E. “Yapay Sinir Ağı (Artificial Neural Network) Nedir?” <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/>, 2 Mayıs 2020. [online].
- [10] <https://www.gtech.com.tr/yapay-sinir-aglari-ve-uygulamalari-1>
- [11] E. Öztemel, *Yapay Sinir Ağları*, Papatya Yayıncılık, 232, İstanbul, 2012.
- [12] Sengoz, N. “Yapay Sinir Ağları”, <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>, 4 Mart 2017. [online].
- [13] F. Bayır, “Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama”, Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, 122s, İstanbul, 2006.
- [14] Köseoğlu, B. “Model Performansını Değerlendirmek: Regresyon”, <https://medium.com/yaz%C4%B1%C4%B1m-ve-bili%C5%9Fim-kul%C3%BCb%C3%BC/model-performans%C4%B1nC4%B1-de%C4%9Ferlendirmek-regresyon-48b4afec8664>, 11 Şubat 2021.